

基于仿真数据与深度学习驱动的液压多路阀故障诊断

徐国勇

上海理工大学机械工程学院, 上海

收稿日期: 2024年2月18日; 录用日期: 2024年3月21日; 发布日期: 2024年3月29日

摘要

多路阀是工程机械液压系统中至关重要的控制元件, 为保证工程机械的安全稳定运行, 需要对多路阀进行准确的故障诊断, 因此本文提出了一种基于一维卷积门控循环网络(1D-CNN + GRU)的多路阀故障诊断方法。首先通过建立多路阀的AMESim仿真模型得到大量的故障样本数据, 解决了深度学习需要大量数据的问题, 并且在样本数据中加入随机噪声模拟实际工作环境的数据; 接着用1D-CNN提取样本数据的空间特征; 然后将提取后的空间特征输入GRU进一步提取时序特征; 最后采用Softmax分类器输出故障诊断结果。实验结果表明, 所提出方法的准确率高于其他故障诊断算法, 故障诊断准确率高于98%。

关键词

多路阀, 深度学习, 故障诊断

Fault Diagnosis of Hydraulic Multiway Valve Driven by Simulation Data and Deep Learning

Guoyong Xu

School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Feb. 18th, 2024; accepted: Mar. 21st, 2024; published: Mar. 29th, 2024

Abstract

The multi-way valve is a crucial control component in the hydraulic systems of engineering machinery. To ensure the safe and stable operation of the machinery, accurate fault diagnosis of the

multi-way valve is necessary. Therefore, this paper proposes a multi-way valve fault diagnosis method based on a one-dimensional convolutional gated recurrent unit network (1D-CGRU). Firstly, a large amount of fault sample data is obtained by establishing an AMESim simulation model of the multi-way valve. This resolves the issue of deep learning requiring a substantial amount of data. Additionally, random noise is added to the sample data to simulate real working conditions. Next, the spatial features of the sample data are extracted using 1D-CNN. Subsequently, the extracted spatial features are input into the GRU to further extract temporal features. Finally, the Softmax classifier is employed to output the fault diagnosis results. Experimental results demonstrate that the proposed method achieves a higher accuracy compared to other fault diagnosis algorithms, with a fault diagnosis accuracy exceeding 98%.

Keywords

Multi-Way Valve, Deep Learning, Fault Diagnosis

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

多路阀由多个电液换向阀组成，是多执行器的液压系统的核心控制元件，广泛应用于移动工程机械(如挖掘机和起重机) [1]。在工程机械的实际应用中，由于负载压力大，执行机构流量大，工作条件变化剧烈频繁，可能会发生严重的液压冲击。而多路阀在这种工况下长时间的工作，很容易产生故障，从而影响控制精度和安全性[2]。多路换向阀存在多种故障，包括油液污染或阀芯频繁往复引起的磨损，以及阀门弹簧疲劳和阀芯卡死等[3]。其中，阀芯磨损与阀芯卡死是最常见的问题。因此，对多路阀进行故障诊断对于避免额外的液压功率损失和提高系统安全性至关重要。

根据故障诊断的理论和方法，液压系统领域常用的方法可分为两类：基于数据的诊断方法和基于模型的诊断方法[4]。在故障数据样本较少的情况下，基于模型的故障诊断方法是通过测量实际结果与模型预测结果的差值进行诊断决策。但是液压系统在不同的故障环境下的输出结果不同，要根据不同环境实时更新仿真模型较难，很难做到对故障的精准诊断。

深度学习是一种常用的数据驱动方法，是从信号中提取出故障的特征后进行故障分类。在液压故障诊断领域展示出强大的能力，也逐渐成为了当前的研究重点。Tang [5]通过连续小波变换得到压力信号的时频特性后构建 BO-LeNet 5 模型对柱塞泵进行故障诊断。Shi [6]从液压换向阀的多维故障信息中提取多维故障特征，在双通道 CNN 中加入注意力机制实现故障诊断。Ji [7]根据对不同故障数据的敏感度选择两种基本分类器(RF、CNN)，然后基于 DS 理论对各分类器的初始结果进行融合，得到最终换向阀的故障诊断结果。Tang [8]构建了 CNN-BO 模型，从声信号的时频图像中学习有用的特征，并对液压柱塞泵的健康状态进行准确的分类。上述方法虽然有较好的故障诊断结果，但依赖于统计模型来确定系统的健康状态。当历史数据不足或操作环境突然发生变化时，这些数据可能不足以实现运行状况监测任务。

基于文献调研，我们发现：1) 基于模型的方法虽然泛化能力较低，但是可以产生大量的带有标签的故障数据。数据驱动方法虽然有很好的诊断能力，但需要大量的带有标签的故障数据作为训练，实际中的液压系统的故障数据又较难获取，因此可以考虑将两种方法的优点相结合。2) 目前液压系统领域的驱动方法大多基于 CNN 的故障诊断模型，而液压系统的原始监测数据是时间序列信号，循环神经网络

(RNN)更适合处理序列数据,善于提取序列数据的整体特征,因此研究基于 RNN 的故障诊断模型是有必要的。

基于上述讨论,本文提出了一种基于一维卷积门控循环网络(1D-CNN + GRU)的多路阀故障诊断方法。该方法通过 1D-CNN 和 GRU 提取样本中的空间特征和时序特征,完成故障诊断。

2. 多路阀仿真模型

2.1. 多路阀工作原理

多路阀由多个工作阀片组成,采用阀前压力补偿形式,各联之间采用并联的方式,使得系统压力损失较小,达到节能的效果,其液压原理图如图 1 所示。




Figure 1. Hydraulic schematic diagram of the multi-way valve: (1) Safety valve; (2) Pressure compensator valve; (3) Proportional directional valve; (4) Shuttle valve; (5) Pressure relief valve; (6) Pressure reducing valve

图 1. 多路阀液压原理图: (1) 安全阀; (2) 压力补偿阀; (3) 比例换向阀; (4) 梭阀; (5) 限压溢流阀; (6) 减压阀

每一联阀片主要由压力补偿阀、比例换向阀、梭阀组成。多路阀各联阀片通过负载敏感通道获取其执行机构压力的大小,最高负载压力通过梭阀反馈给单向压力补偿阀和负载敏感变量泵的负载敏感阀。通过反馈使换向阀的阀前压力与当前工作联负载压力保持不变,始终为压力补偿器的弹簧预调力。主阀输出流量保持不变,从而使执行机构的速度不会受到负载压力变化的影响。在主阀开度一定的情况下,主阀输出流量保持不变,从而使执行机构的速度不会受到负载压力变化的影响。

2.2. 多路阀数学模型推导及仿真模型建立

针对比例换向阀、压力补偿阀这些核心原件的工作原理分别建立数学模型，分述如下：

1) 主阀芯模块

根据牛顿第二定律得到主阀的阀芯运动微分方程：

$$p_1 A_1 - p_2 A_2 - K_1 (x_v + x_{10}) - \zeta_1 \dot{x}_1 = m_1 \ddot{x}_v \quad (1)$$

其中， p_1 是主阀右端无杆腔压力； p_2 是主阀左端无杆腔压力； A_1 是主阀右端无杆腔有效作用面积； A_2 是主阀左端无杆腔有效作用面积； K_1 是主阀弹簧刚度； x_v 是主阀的阀芯位移； x_{10} 是主阀弹簧初始拉伸量； ζ_1 是主阀粘性阻尼系数； m_1 是主阀的阀芯等效质量。

阀流量压力方程：

$$Q_v = C_{dv} x_v w_v \sqrt{\frac{\Delta p_v}{\rho}} \quad (2)$$

其中， Q_v 是流过主阀流量， C_{dv} 是阀芯流量系数， w_v 是阀芯面积梯度， Δp_v 是主阀前后压差， ρ 是油液密度。

理论流量求解：

$$Q_0 = C_{dv} x_{v\max} w_v \sqrt{\frac{P_0}{\rho}} \quad (3)$$

其中， P_0 是额定压降， Q_0 是最大空载流量，即可获得理论阀系数：

$$K_q = \frac{\sqrt{P_c - P_t}}{x_{v\max} \sqrt{P_0}} Q_0 \quad (4)$$

假设阀芯左移为正方向 $x_v \geq 0$ ，阀芯右移为负方向 $x_v < 0$ ，根据公式(2)，当阀芯左移 $x_v \geq 0$ 时多路阀流量方程：

$$\begin{aligned} Q_{va} &= K_q x_v \sqrt{p_c - p_a} \\ Q_{vb} &= K_q x_v \sqrt{p_b - p_t} \\ Q_L &= Q_{va} \end{aligned} \quad (5)$$

当阀芯右移 $x_v < 0$ 时多路阀流量方程：

$$\begin{aligned} Q_{va} &= K_q x_v \sqrt{p_c - p_t} \\ Q_{vb} &= K_q x_v \sqrt{p_c - p_b} \\ Q_L &= Q_{vb} \end{aligned} \quad (6)$$

2) 压力补偿阀模块

根据牛顿第二定律得到压力补偿阀的阀芯运动微分方程：

$$p_3 A_3 - p_4 A_4 - K_2 (x_1 + x_{20}) - \zeta_2 \dot{x}_2 = m_2 \ddot{x}_2 \quad (7)$$

其中， p_3 是压力补偿阀右端无杆腔压力； p_4 是压力补偿阀左端无杆腔压力； A_3 是压力补偿阀右端无杆腔有效作用面积； A_4 是压力补偿阀左端无杆腔有效作用面积； K_2 是压力补偿阀弹簧刚度； x_1 是压力补偿阀的阀芯位移； x_{20} 是压力补偿阀弹簧初始拉伸量； ζ_2 是压力补偿阀粘性阻尼系数； m_2 是压力补偿阀的阀芯等效质量。

压力阀开口面积可以表达为:

$$S_{rc}(\Delta P_{XY}) = S_{rc\max} - k_{rc}(\Delta P_{XY} - \Delta P_{rcset}) \quad (8)$$

其中, ΔP_{XY} 是补偿阀两端压差, $S_{rc}(\Delta P_{XY})$ 是补偿阀开口面积, $S_{rc\max}$ 是补偿阀最大开口面积, ΔP_{rcset} 是补偿阀调定压力, k_{rc} 是补偿阀压力-面积系数。

k_{rc} 的表达式为:

$$k_{rc} = \frac{S_{rc\max} - S_{rcleak}}{\Delta P_{rcreg}} \quad (9)$$

其中, S_{rcleak} 是补偿阀泄漏面积, ΔP_{rcreg} 是压力调节范围。

补偿阀两端压差在调定压力以下时:

$$S_{rc}(\Delta P_{XY} \leq \Delta P_{rcset}) = S_{rc\max} \quad (10)$$

补偿阀两端压差在最大压力以上时:

$$S_{rc}(\Delta P_{XY} \geq \Delta P_{rc\max}) = S_{rcleak} \quad (11)$$

其中, $\Delta P_{rc\max}$ 是补偿阀最大压差, 其表达式为:

$$\Delta P_{rc\max} = \Delta P_{rcset} + \Delta P_{rcreg} \quad (12)$$

通过补偿阀的流量为:

$$q_{rc} = C_{dc} S_{rc} \sqrt{\frac{2\Delta P_{rc}}{\rho}} \quad (13)$$

2.3. 仿真模型建立

在数学模型的基础上, 为方便对参数进行调整以及获取故障诊断的原始数据, 在 AMESim 中根据多路阀数学模型和工作原理建立仿真模型, 如图 2 所示, 通过计算测试, 负载敏感多路阀主要仿真调试参数如表 1 所示。

建立了两个工作联, 每个工作联包括主阀芯、压力补偿阀以及模拟负载的比例溢流阀。负载敏感泵为两个工作阀片供油。

Table 1. Primary parameters of the multi-way valve

表 1. 多路阀主要参数

序号	参数	值	序号	参数	值
1	压力补偿阀阀芯质量	0.1 kg	6	压力补偿阀活塞直径	20 mm
2	压力补偿阀活塞杆直径	8 mm	7	压力补偿阀弹簧刚度	25 N/mm
3	压力补偿阀弹簧预调力	80 N	8	压力补偿阀槽口数目	4
4	主阀活塞直径	21 mm	9	主阀活塞杆直径	11 mm
5	主阀槽口数目	4	10	主阀槽口宽度	2 mm

3. 故障诊断模型准备

3.1. 门控循环神经网络

门控循环神经网络(GRU)由长短期记忆网络(LSTM)改进而来, 二者都属于 RNN 的一种。GRU 网络作为 LSTM 网络的一种变体, 将 LSTM 中的输入门和遗忘门合成一个单一的更新门, 并保留重置门, 在

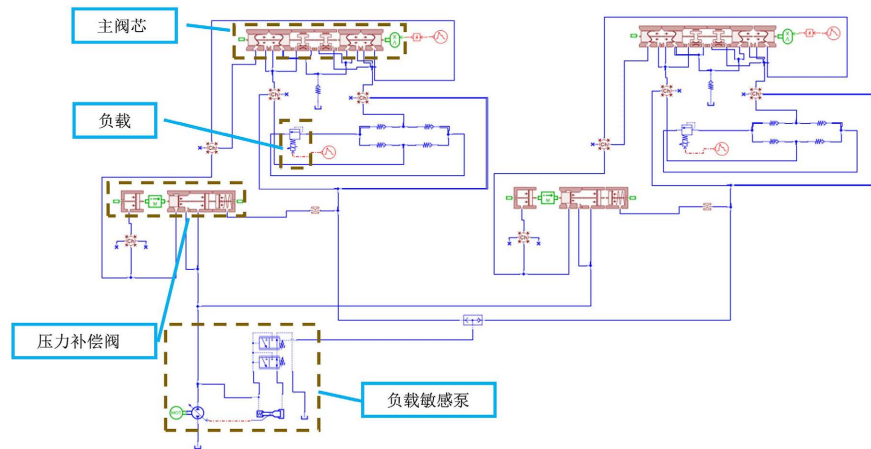


Figure 2. Multi-way valve simulation model
图 2. 多路阀仿真模型

保证了预测效果的同时精简了结构，减少了训练参数。GRU 的核心思想是使用两个门控单元来控制信息的流动，分别是重置门和更新门。重置门决定了前一个隐状态对当前隐状态的影响程度，更新门决定了当前隐状态对下一个隐状态的影响程度。通过这种方式，GRU 可以有效地保留长期依赖的信息，并且减少了参数的数量，提高了计算效率。GRU 的详细内部结构如图 3 所示。数学表达式为：

$$\begin{cases} z_t = \sigma(W_z[h_{t-1}, x_t] + b_z) \\ r_t = \sigma(W_r[h_{t-1}, x_t] + b_r) \\ \tilde{h}_t = \tanh(W_h[r_t * h_{t-1}, x_t] + b_h) \\ h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \end{cases} \quad (14)$$

在 t 时刻，GRU 的输入为 x_t ，前一时刻输入的隐藏状态为 h_{t-1} 。GRU 首先计算重置门 r_t 和更新门 z_t ，然后根据 r_t 和 h_{t-1} 计算候选隐藏状态 \tilde{h}_t ，最后根据 z_t 、 h_{t-1} 和 \tilde{h}_t 计算当前隐藏状态 h_t 。其中， W_r 、 W_z 、 W_h ——重置门、更新门和 \tilde{h}_t 对应的权重矩阵， b_r 、 b_z 、 b_h ——重置门、更新门和 \tilde{h}_t 对应的偏置矩阵， $\sigma(x)$ ——sigmoid 激活函数。最后，由隐状态 h_t 来进行各单元间的信息传递。




Figure 3. Diagram of the GRU network unit structure
图 3. GRU 网络单元结构图

3.2. 卷积神经网络

CNN 拥有很好的空间特征提取能力[9]。在 CNN 中，共享权值可以有效避免算法的过拟合，而稀疏连接可以减少训练参数的数量。一维卷积神经网络(1D-CNN)常用于时间序列，其卷积输出是一维的。1D-CNN 的计算细节如下所示。假设序列输入数据为 $X = [x_1, x_2, \dots, x_n] \in R^{d \times n}$ ，其中 d 和 n 分别表示输入序列的维数和长度。卷积层被看作是数字滤波器的集合，它将多个局部滤波器与原始输入数据进行卷积，并生成相应的局部特征。具体的卷积运算如下所示：

$$c_i = \varphi(\omega \cdot x_{i:i+m-1} + b) \quad (15)$$

设 $\omega \in R^{d \times m}$ 表示滤波器向量； $x_{i:i+m-1}$ 表示从第 i 个时间步长开始的 m 长度的滑动窗口； φ 和 b 分别表示非线性激活函数和偏置； c_i 表示滤波器 ω 对相应子序列 $x_{i:i+m-1}$ 的激活。将滤波窗口从开始时间步向结束时间步滑动，即可获得特征图。池化层的目的是减少特征映射的长度，遵循几个规则，包括平均值和最大值。

3.3. 提出的故障诊断方法

构建 1D-CNN 和 GRU 的混合神经网络的基本思想是将 1D-CNN 和 GRU 两种深度学习方法串联起来，其中 1D-CNN 是串联网的初级网络，GRU 是次级网络系列网络的网络。所提出的串联网结构如图 4 所示，包括输入层、隐藏层和输出层。隐藏层由一个卷积层、一个池化层、一个 GRU 层以及一个全连接层组成，最后通过 Softmax 分类器对 GRU 输出进行分类。本文所提出的方法可识别故障的时间特性，在 GRU 之前使用 1D-CNN 作为预处理步骤来处理长时间序列，可将故障在时间顺序上进行分类。1D-CNN 通过卷积层获取原始序列数据的特征。把 1D-CNN 特征作为 GRU 的输入，最终得到分类结果。




Figure 4. Diagram of the proposed cascaded network architecture

图 4. 所提出的串联网结构

4. 实验验证

4.1. 数据集说明

本文总共设置 15 组实验，用于获取多路阀不同的健康状态。其中主要设置了阀芯卡死和阀芯磨损两种故障，具体故障类型如表 2 所示，其中列出了多路阀的 1 种正常状态和 14 种故障及其对应位置以及标签。每种故障数据集包含 300 个样本，包含原始仿真数据以及加了 4 db 噪声的数据。选用 50% 的数据作为训练集，25% 的数据作为验证集，25% 的数据作为测试集。

4.2. 对比实验

为了验证所提出模型的性能，本文构建了 GRU 和 LSTM 作为对比模型。模型的具体参数设置如下：

GRU：使用 1 个具有 8 个单元的 GRU 层，激活函数为 ReLU，采用 Adam 优化器更新参数，学习率设置为 0.0001。

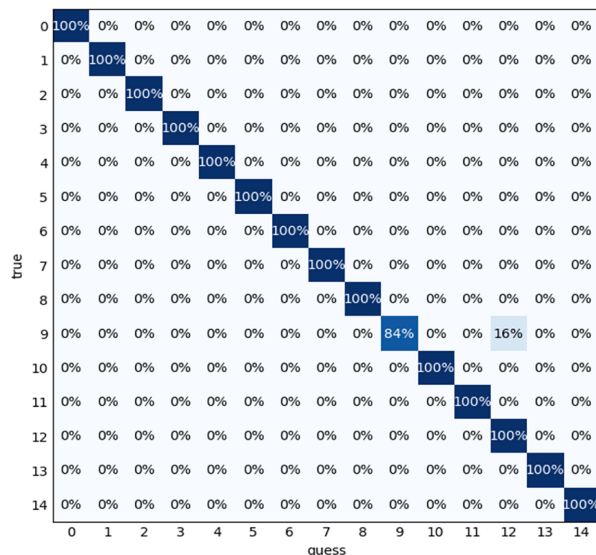
Table 2. Explanation of the health condition of the multi-way valve
表 2. 多路阀健康状况说明

故障类型	故障描述	标签
	死区位置卡死	0
	阀芯位移至 3 mm 处卡死	1
	阀芯位移至 4 mm 处卡死	2
	阀芯位移至 5 mm 处卡死	3
	阀芯位移至 6 mm 处卡死	4
阀芯卡死	阀芯位移至 7 mm 处卡死	5
	阀芯位移至-3 mm 处卡死	6
	阀芯位移至-4 mm 处卡死	7
	阀芯位移至-5 mm 处卡死	8
	阀芯位移至-6 mm 处卡死	9
	阀芯位移至-7 mm 处卡死	10
阀芯无故障	正常	11
阀芯轻度磨损	阀芯与阀体间隙 0.01 mm~0.25 mm	12
阀芯轻度磨损	阀芯与阀体间隙 0.25 mm~0.35 mm	13
阀芯轻度磨损	阀芯与阀体间隙 0.35 mm~0.45 mm	14

LSTM: 使用 2 个具有 16 个单元的 LSTM 层，激活函数为 ReLU，采用 Adam 优化器更新参数，学习率设置为 0.0001。

本文以准确率作为评价指标，将对比较模型与 1D-CNN + GRU 模型进行了比较研究，预测结果如图 5 所示。

从表 3 以及图 5 可以看出 1D-CNN + GRU 相比 GRU 和 LSTM 准确率分别提升了 5.86% 和 7.2%，具有较高的预测可靠性。相比于 GRU 和 LSTM，本文所提出的模型将 GRU 与 1D-CNN 相结合，对多路阀中不同的特征进行区分，对关键信息给予更高的关注，有效的增加了多路阀故障诊断的精度。



1D-CNN+GRU
 (a) 1D-CNN + GRU

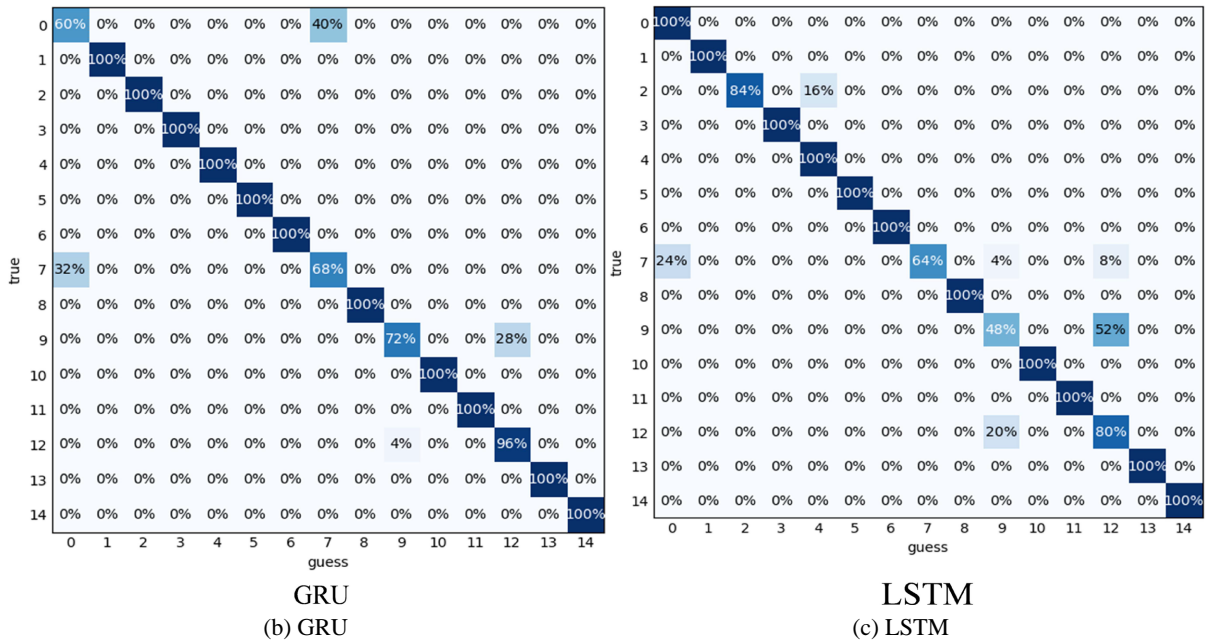


Figure 5. Confusion matrix results of different fault diagnosis algorithms
图 5. 不同故障诊断算法的混淆矩阵结果

Table 3. Accuracy rates of different algorithms
表 3. 不同算法的准确率

网络类型	准确率
1D-CNN + GRU	98.93%
GRU	93.07%
LSTM	91.73%

5. 结论

本文研究液压多路阀的故障诊断，利用液压压力信号的时间序列数据进行分析。为了充分利用这些数据，采用参数较少的 GRU 来挖掘时间序列特征。同时，结合 CNN 强大的空间特征提取能力，提出了一种基于 1D-CNN + GRU 的多路阀故障诊断方法。首先，通过建立多路阀的 AMESim 仿真模型获取大量故障样本数据。然后，使用 1D-CNN 提取样本数据的局部特征。接下来，将每个样本的局部特征输入 GRU 模型，进一步提取时序特征。最后，通过 Softmax 分类器输出故障诊断结果。与 GRU、LSTM 模型相比，实验结果表明，本文提出的 1D-CNN + GRU 模型具有更高的故障诊断准确率，展现出更强的故障诊断能力。

参考文献

- [1] 付松松, 李卫民. 多路阀阀芯节流槽拓扑结构的优化设计[J]. 机床与液压, 2023, 51(21): 185-192.
- [2] Ye, Z., Zhang, H., Wang, Y., et al. (2015) Analysis of Proportional Multi-Way Directional Valve Fault Simulation. 2015 International Conference on Fluid Power and Mechatronics (FPM), Harbin, 5-7 August 2015, 328-331. <https://doi.org/10.1109/FPM.2015.7337134>
- [3] Shi, C., Ren, Y., Tang, H. and Mupfukirei, L.R. (2021) A Fault Diagnosis Method for an Electro-Hydraulic Directional

-
- Valve Based on Intrinsic Mode Functions and Weighted Densely Connected Convolutional Networks. *Measurement Science and Technology*, **32**, Article 084015. <https://doi.org/10.1088/1361-6501/abfad2>
- [4] 何深, 陈俊, 战家乙. 板式换热器仿真及诊断研究[J]. 暖通空调, 2021, 51(S2): 276-279.
- [5] Tang, S., Zhu, Y. and Yuan, S. (2022) An Adaptive Deep Learning Model towards Fault Diagnosis of Hydraulic Piston Pump Using Pressure Signal. *Engineering Failure Analysis*, **138**, Article ID: 106300. <https://doi.org/10.1016/j.engfailanal.2022.106300>
- [6] Shi, J.C., Ren, Y., Tang, H.S. and Xiang, J.W. (2022) Hydraulic Directional Valve Fault Diagnosis Using a Weighted Adaptive Fusion of Multi-Dimensional Features of a Multi-Sensor. *Journal of Zhejiang University-SCIENCE A*, **23**, 257-271. <https://doi.org/10.1631/jzus.A2100394>
- [7] Ji, X., Ren, Y., Tang, H., Shi, C. and Xiang, J. (2020) An Intelligent Fault Diagnosis Approach Based on Dempster-Shafer Theory for Hydraulic Valves. *Measurement*, **165**, Article ID: 108129. <https://doi.org/10.1016/j.measurement.2020.108129>
- [8] Tang, S., Zhu, Y. and Yuan, S. (2022) A Novel Adaptive Convolutional Neural Network for Fault Diagnosis of Hydraulic Piston Pump with Acoustic Images. *Advanced Engineering Informatics*, **52**, Article ID: 101554. <https://doi.org/10.1016/j.aei.2022.101554>
- [9] 张伟, 张广帅, 王连彪. 基于 CNN-GRU 网络的轴承故障检测算法[J]. 工业仪表与自动化装置, 2021(6): 88-91.